

# MAP433 Statistique

## PC2: Modélisation statistique

5 septembre 2014

### 1 Stabilisation de la variance

On dispose d'un échantillon  $X_1, \dots, X_n$  i.i.d. de loi de Bernoulli de paramètre  $0 < \theta < 1$ .

1. On note  $\bar{X}_n$  la moyenne empirique des  $X_i$ . Que disent la loi des grands nombres et le TCL ?
2. Cherchez une fonction  $g$  telle que  $\sqrt{n}(g(\bar{X}_n) - g(\theta))$  converge en loi vers  $Z$  de loi  $\mathcal{N}(0, 1)$ .
3. On note  $z_\alpha$  le quantile d'ordre  $1 - \alpha/2$  de la loi normale standard. En déduire un intervalle  $\hat{I}_{n,\alpha}$  fonction de  $z_\alpha, n, \bar{X}_n$  tel que  $\lim_{n \rightarrow \infty} \mathbb{P}(\theta \in \hat{I}_{n,\alpha}) = 1 - \alpha$ .

### 2 Modèle exponentiel

Une grande partie des modèles utilisés en pratique sont des modèles exponentiels (modèle gaussien, log-normal, exponentiel, gamma, Bernoulli, Poisson, etc). Nous allons étudier quelques propriétés de ces modèles. On appelle modèle exponentiel une famille de lois  $\{\mathbb{P}_\theta, \theta \in \Theta\}$  ayant une densité par rapport à une mesure  $\mu$   $\sigma$ -finie sur  $\mathbb{R}$  ou  $\mathbb{N}$  de la forme

$$p_\theta(x) = c(\theta) \exp(m(\theta)f(x) + h(x)).$$

On supposera que  $\Theta$  est un intervalle ouvert de  $\mathbb{R}$ ,  $m(\theta) = \theta$  et  $c(\cdot) \in C^2$ ,  $c(\theta) > 0$  pour tout  $\theta \in \Theta$ . On notera  $X$  une variable aléatoire de loi  $\mathbb{P}_\theta$  et on admettra que

$$\frac{d^i}{d\theta^i} \int \exp(\theta f(x) + h(x)) \mu(dx) = \int f(x)^i \exp(\theta f(x) + h(x)) \mu(dx) < +\infty, \quad \text{pour } i = 1, 2.$$

1. Montrez que  $\varphi(\theta) := \mathbb{E}_\theta(f(X)) = -\frac{d}{d\theta} \log(c(\theta))$ .
2. Montrez que  $\text{Var}_\theta(f(X)) = \varphi'(\theta) = -\frac{d^2}{d\theta^2} \log(c(\theta))$ .
3. On dispose d'un  $n$ -échantillon  $X_1, \dots, X_n$  de loi  $\mathbb{P}_\theta$ . On note  $\hat{\theta}_n$  l'estimateur obtenu en résolvant  $\varphi(\hat{\theta}_n) = \frac{1}{n} \sum_{i=1}^n f(X_i)$ . En supposant  $\text{Var}_\theta(f(X)) > 0$ , montrez que

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{\text{loi}} \mathcal{N}\left(0, \frac{1}{\text{Var}_\theta(f(X))}\right).$$

### 3 Modèle probit

Nous disposons d'une information relative au comportement de remboursement ou de non-remboursement d'emprunteurs :

$$Y_i = \begin{cases} 1 & \text{si l'emprunteur } i \text{ rembourse,} \\ 0 & \text{si l'emprunteur } i \text{ est défaillant.} \end{cases}$$

Afin de modéliser ce phénomène, on suppose l'existence d'une variable aléatoire  $Y_i^*$  normale, d'espérance  $m$  et de variance  $\sigma^2$ , que l'on appellera « capacité de remboursement de l'individu  $i$  », telle que :

$$Y_i = \begin{cases} 1 & \text{si } Y_i^* > 0, \\ 0 & \text{si } Y_i^* \leq 0. \end{cases}$$

On note  $\Phi$  la fonction de répartition de la loi normale  $\mathcal{N}(0, 1)$ .

1. Exprimer la loi de  $Y_i$  en fonction de  $\Phi$ .
2. Les paramètres  $m$  et  $\sigma^2$  sont-ils identifiables ?

### 4 Modèle d'autorégression

On considère l'observation  $Z = (X_1, \dots, X_n)$ , où les  $X_i$  sont issus du processus d'autorégression :

$$X_i = \theta X_{i-1} + \xi_i, \quad i = 1, \dots, n, \quad X_0 = 0,$$

avec les  $\xi_i$  i.i.d. de loi normale  $\mathcal{N}(0, \sigma^2)$  et  $\theta \in \mathbb{R}$ . Écrire le modèle statistique engendré par l'observation  $Z$ .

### 5 Durée de vie

Un système fonctionne en utilisant deux machines de types différents. Les durées de vie  $X_1$  et  $X_2$  des deux machines suivent des lois exponentielles de paramètres  $\lambda_1$  et  $\lambda_2$ . Les variables aléatoires  $X_1$  et  $X_2$  sont supposées indépendantes.

1. Montrer que une variable aléatoire  $X$  suit la loi exponentielle  $\mathcal{E}(\lambda)$  si et seulement si

$$\forall x > 0 : P(X > x) = \exp(-\lambda x).$$

2. Calculer la probabilité pour que le système ne tombe pas en panne avant la date  $t$ . En déduire la loi de la durée de vie  $Z$  du système. Calculer la probabilité pour que la panne du système soit due à une défaillance de la machine 1.
3. Soit  $I = 1$  si la panne du système est due à une défaillance de la machine 1,  $I = 0$  sinon. Calculer  $P(Z > t; I = \delta)$ , pour tout  $t \geq 0$  et  $\delta \in \{0, 1\}$ . En déduire que  $Z$  et  $I$  sont indépendantes.
4. On dispose de  $n$  systèmes identiques et fonctionnant indépendamment les uns des autres dont on observe les durées de vie  $Z_1, \dots, Z_n$ .
  - (a) Écrire le modèle statistique correspondant. Les paramètres  $\lambda_1$  et  $\lambda_2$  sont-ils identifiables ?
  - (b) Supposons maintenant que l'on observe à la fois les durées de vie des systèmes  $Z_1, \dots, Z_n$  et les causes de la défaillance correspondantes  $I_1, \dots, I_n$ ,  $I_i \in \{0, 1\}$ . Écrire le modèle statistique dans ce cas. Les paramètres  $\lambda_1$  et  $\lambda_2$  sont-ils identifiables ?